

BAB 2

KAJIAN PUSTAKA DAN KERANGKA BERPIKIR

2.1 Kajian Pustaka

Kajian pustaka terdiri dari uraian penelitian-penelitian terdahulu yang terkait dengan topik penelitian. Dalam penelitian ini, studi literatur mengenai intensitas guncangan, respons seismik sistem interaksi tanah-struktur, dan pemanfaatan kecerdasan buatan (AI) dalam teknik kegempaan akan diuraikan.

2.1.1 Intensitas Guncangan

Intensitas guncangan atau intensitas seismik adalah besaran angka yang menggambarkan tingkat keparahan suatu kejadian gempa bumi ditinjau dari dampaknya pada permukaan bumi, manusia, dan struktur-strukturnya (United States Geological Survey (USGS), 2021). Besaran yang diklasifikasikan dalam berbagai jenis skala ini diimplementasikan baik pada fase desain maupun mitigasi bencana.

2.1.1.1 Skala Intensitas Guncangan

Ada beberapa jenis skala intensitas guncangan akibat gempa yang diterapkan di berbagai tempat. Skala Rossi-Forel (1883) adalah skala intensitas yang masih diterapkan di beberapa bagian Eropa. Skala Mercalli-Cancani-Sieberg, yang dikombinasikan dengan Mercalli (1902) dan Cancani (1904), masih banyak digunakan di Eropa Barat. Skala *Modified Mercalli* (MM) yang diusulkan oleh Neumann pada tahun 1931, merupakan salah satu skala intensitas yang banyak digunakan di seluruh bagian dunia saat ini. Studi mengenai perbandingan beberapa skala intensitas seismik berdasarkan tingkat kerusakan struktur dilakukan oleh (Li et al., 2021), khususnya untuk *European Macroseismic Scale* (EMS), *Medvedev-Sponheuer-Karnik* (MSK)-81, dan *Chinese Seismic Intensity Scale* (CSIS). Selain beberapa skala intensitas seismik yang telah disebutkan, terdapat juga skala intensitas seismik yang dikembangkan oleh *Japan Meteorological Agency* (JMA), yaitu *Seismic Intensity Scale* (SIS).

Berbeda dengan skala intensitas pada umumnya yang merupakan deskripsi kualitatif dari dampak gempa bumi, SIS (dalam bahasa Jepang, *Shindo*) yang dikembangkan oleh JMA dapat dihitung secara kuantitatif. Perhitungan nilai SIS dan sistem kategorinya dapat dilihat pada sub-bab 2.2.1. Studi mengenai kuantifikasi SIS diinisiasi oleh Kawasumi (1943) yang perhitungannya dijadikan pedoman oleh JMA dan

diteliti lebih lanjut dengan membandingkan metode analisisnya dengan metode FAS (*Fourier Amplitude Spectra-intensity*) (Sokolov and Furumura, 2008). Pengembangan intensif mengenai SIS dilakukan oleh Sakai (2015) yang memformulasikan intensitas seismik pada periode panjang dan proses filtrasi yang mendasarinya (Sakai, 2018a). Selain itu, generalisasi dan perbandingan metode perhitungan intensitas seismik menggunakan beberapa parameter seismik juga diteliti oleh Sakai (2018b).

Penelitian terkait SIS pernah dilakukan oleh Karim dan Yamazaki (2002), yang menunjukkan bahwa SIS memiliki tingkat korelasi tertinggi dengan *Spectrum Intensity* (SI) dibandingkan dengan indikator seismik lainnya yaitu *Peak Ground Acceleration* (PGA) dan *Peak Ground Velocity* (PGV). Penelitian lebih lanjut yang memanfaatkan SIS untuk memprediksi gerakan tanah pada gempa-gempa sesar dangkal dilakukan oleh Campbell dan Bozorgnia (2010).

2.1.1.2 Skala Intensitas Guncangan untuk Desain dan Perkuatan Bangunan

Studi mengenai pentingnya kuantifikasi guncangan dalam filosofi desain bangunan dilakukan oleh Wariyatno (2019). Dalam Wariyatno et al. (2019), batas intensitas guncangan gempa besar disarankan untuk diperhitungkan dalam desain/perencanaan struktur. Perkembangan riset mengenai salah satu skala intensitas guncangan yang diterapkan khususnya di Jepang, yaitu *Seismic Intensity Level* (SIL), telah mencapai penemuan perhitungan kuantitatif guncangan pada tiap lantai bangunan (Wariyatno, 2022).

Pada penelitian yang sama, sebuah model hubungan spektrum respons dengan nilai *mSIL* secara kuantitatif untuk perhitungan intensitas guncangan saat perencanaan bangunan tahan gempa telah dikembangkan. Penelitian ini melibatkan tiga model spektrum respons, masing-masing terdiri dari 100 variasi, yang digunakan untuk membuat gempa tiruan. Selanjutnya, perhitungan *mSIL* dilakukan dengan mengacu pada standar dari Japan Meteorological Agency (JMA). Hasil dari penelitian ini adalah aplikasi *rs_mSIL* untuk menghitung intensitas guncangan di permukaan tanah berdasarkan spektrum respons dan aplikasi *lt_mSIL* untuk menghitung intensitas guncangan pada tiap lantai bangunan. Kedua aplikasi ini dapat diterapkan untuk menyajikan data intensitas guncangan bangunan saat terjadi gempa.

Penerapan kuantifikasi intensitas guncangan pada evaluasi kinerja tingkat kenyamanan bangunan tahan gempa dengan variasi perkuatan (*strengthening*) diteliti

oleh Wariyatno et al. (2021). Dalam penelitian ini terdapat tiga (3) jenis sistem bangunan yaitu bangunan sistem rangka pemikul momen (SRPM atau MRF), bangunan dengan *bracing* (BRF), dan bangunan dengan *Base Isolation* (BI). Model numerik dikembangkan untuk ketiga jenis bangunan ini dan dikenai oleh beberapa tipe beban gempa tiruan, yaitu Big Bear 1992, El Centro 1940, Kobe 1995, Loma Prieta 1989, Morgan Hill 1984, Mammoth Lake 1980, dan Northridge 1994. Penelitian ini menghasilkan kesimpulan bahwa bangunan dengan BI memiliki nilai SIL paling rendah (antara 3-4), diikuti BRF (antara 5 *weak* – 5 *strong*), dan MRF (antara 6 *weak* – 6 *strong*). Hal ini menguatkan pernyataan di atas bahwa evaluasi kinerja tingkat kenyamanan, yang salah satunya berupa intensitas guncangan, harus dipertimbangkan dalam fase desain sebuah bangunan.

2.1.1.3 Mitigasi Bencana Gempa Bumi berbasis SIS

Penerapan skala intensitas seismik tidak hanya berlaku pada tahap desain bangunan, melainkan juga pada tahap evaluasi dan mitigasi bencana. Studi mengenai evaluasi dalam rangka mitigasi bencana gempa bumi telah dilakukan oleh Wu et al. (2016), yang mengembangkan kurva kerentanan (*fragility*) empiris berdasarkan korelasi antara indikator kerusakan gedung dan gerakan tanah pascagempa Tohoku 2011. Kodera et al. (2016) melakukan evaluasi terhadap kinerja sistem peringatan dini berbasis SIS pascagempa Kumamoto. Selain itu, laporan-laporan peninjauan pascabencana gempa dengan intensitas guncangan 7 (skala JMA) telah ditulis oleh Mukunoki et al. (2016) dalam merespons gempa Kumamoto tahun 2016 dan Ishikawa et al. (2021) untuk gempa Iburi Timur Hokkaido tahun 2018.

2.1.2 Respons Seismik Interaksi Tanah-Struktur

Distribusi dan perilaku gempa di permukaan tanah sangat dipengaruhi oleh properti mekanis dan dinamis dari tanah di bawahnya (Kramer, 1996). El-Azab, Mahmoud and Abd-Elhameed (2011) mencatat bahwa fleksibilitas tanah dapat mengamplifikasi respons puncak dari bangunan pada periode alami rendah. Selain itu, kecepatan gelombang geser menunjukkan perubahan signifikan pada amplifikasi respons dinamik puncak dan tidak signifikan pada periode alami tinggi. Studi lebih lanjut mengenai parameter dinamik tanah dan fondasi dilakukan oleh Li, Escoffier and Kotronis (2020), Cao et al. (2022), Liu et al. (2023), Sutaih and Aggour (2022), dan Chang, Cheng and Wang (2014).

Penelitian mengenai model interaksi tanah-struktur dan perilaku seismiknya dilakukan oleh Ahmadi et al. (2015). Pada penelitian ini, struktur dimodelkan dalam

bentuk *shear building* (MDOF) dengan model kerucut (*the cone model*) pada bagian fondasinya (Ahmadi et al., 2018). Pembebanan seismik dimodelkan dengan kumpulan gerakan tanah dari 59 data riwayat waktu untuk kelas tanah D dan E. Berdasarkan hasil pengujian, redaman material tanah (*soil material damping*) harus diperhitungkan dalam analisis seismik sistem interaksi tanah-struktur ketika struktur atas langsing. Semakin tinggi tingkat lantai, semakin jelas respons yang diakibatkan oleh redaman material tanah (*soil material damping*).

2.1.3 Artificial Intelligence dalam Kegempaan dan Mitigasinya

Kecerdasan buatan atau *artificial intelligence* (AI) secara historis sangat berkaitan dengan ilmu-ilmu lain seperti matematika, astronomi, dan fisika (Sun dan Cristea, 2023). Dalam bidang seismologi, AI mula-mula digunakan dalam mendeteksi gempa dini dan sinyal seismik gunung berapi dari sekumpulan besar sinyal-sinyal gelombang dan mampu membedakan antara sinyal yang valid dan suara-suara bising (*noises*). Perkembangan terkini mengenai penggunaan AI dalam teknik kegempaan ditunjukkan oleh beberapa penelitian antara lain, *Machine Learning* (ML) untuk mengestimasi amplifikasi situs seismik (Díaz et al., 2022) dan prediksi respons seismik tanah menggunakan dua teknik ML yaitu *convolution neural network* (CNN) dan *long short-term memory* (LSTM) yang berhasil mereduksi kesalahan prediksi dengan metode *finite element method* (FEM) sebesar 40% pada domain waktu dan 30% pada domain frekuensi (Li et al., 2023).

2.1.3.1 Prediksi Perilaku Seismik Struktur Berbasis AI

Studi mengenai prediksi perilaku seismik struktur dan kekuatannya menggunakan teknik-teknik dalam AI terus dikembangkan. Dalam infrastruktur gedung, penelitian telah dilakukan untuk memprediksi respons seismik dari portal beton bertulang menggunakan bantuan AI (Luo and Paal, 2022). Prediksi fisibilitas teknik terhadap kekuatan seismik pada struktur beton bertulang eksisting menggunakan *artificial neural network* (ANN) diteliti oleh Falcone et al. (2022). Pada ranah jembatan, Zhang et al. (2023) mengaplikasikan beberapa teknik dalam ML, seperti Conv1D-LSTM, XGBoost, dan *Random Forest Regression* (RFR) untuk memprediksi kinerja seismik dari *the precast segmental self-centering concrete-filled steel tube* (PCFST). Untuk infrastruktur keairan, respons seismik nonlinear dari menara *intake-outlet* diprediksi perpindahan dan kerusakan tariknya dengan menggunakan ANN (Bigdeli et al., 2023). Secara umum

dalam penelitian-penelitian tersebut, pendekatan kecerdasan buatan mampu menghasilkan prediksi yang akurat dan efisien dari segi waktu.

2.1.3.2 Prediksi Nilai Intensitas Guncangan Bangunan Berbasis AI


Pengembangan metode *Deep Neural Network* (DNN), yang merupakan bagian dari teknologi kecerdasan buatan (*artificial intelligence/AI*) untuk melakukan prediksi nilai intensitas guncangan bangunan akibat gempa, dilakukan oleh Gan (2023). Himpunan data (*dataset*) yang dijalankan pada metode ini meliputi data-data dasar gempa (magnitudo, jarak episentrum, dan kedalaman), identifikasi lantai bangunan, dan nilai SIS. Sejumlah 3000 data digunakan sebagai data pembelajaran (*training*) dalam DNN, sedangkan 312 data untuk validasi. Model dilatih untuk 30 langkah pembelajaran (*epochs*) menggunakan *mini-batch* ukuran 64 (8x8). Pada setiap iterasi, seluruh data diacak dan diiterasikan pada area *mini-batch*. Di akhir setiap iterasi, pada masing-masing *mini-batch* dilakukan evaluasi terhadap *mode-loss* dan gradien data, lalu dilakukan pembaharuan parameter jaringan. Arsitektur model CNN yang dikembangkan pada penelitian Gan (2023) ditunjukkan pada Gambar 2.1.

Dari hasil studi yang dilakukan, konvergensi dari model DNN yang dikembangkan terjadi dengan sangat cepat, yaitu mendekati *zero loss* dalam kurang dari 500 iterasi. Berdasarkan hasil validasi terhadap 312 data baru, akurasi prediksi nilai SIS pada lantai dasar dan atap menghasilkan galat di bawah 10%, sedangkan pada lantai yang lain, galat terbesar adalah sekitar 20%. Hal ini mengonfirmasi bahwa metode DNN sangat berpotensi dikembangkan dalam sistem mitigasi bencana khususnya sistem peringatan dini gempa, yang memerlukan akurasi dan kecepatan tinggi.

2.1.3.3 AI dalam Sistem Peringatan Dini Gempa

Pengembangan sistem peringatan dini bencana gempa bumi (*earthquake early warning system*) merupakan bagian yang tidak lepas dari pengaruh perkembangan teknologi kecerdasan buatan. Metode kombinasi antara *recurrent neural network* (RNN) dan *transfer learning* terbukti dapat memprediksi PGA dan PGV pada instrumentasi seismik di China, bahkan mencapai 90% alarm benar dan 10% alarm salah di daerah dekat episentrum (Zhu et al., 2023). Sementara itu, metode LSTM dan CNN diuji aplikasinya dalam memprediksi intensitas dan lokasi kejadian seismik di Chile, dan menghasilkan angka $R^2 = 0,66$ untuk prediksi intensitas maksimum menggunakan LSTM, sedangkan akurasi 80% dan 45% dicapai oleh metode CNN untuk memprediksi probabilitas kejadian

gempa yang akan datang untuk magnitudo lebih dari atau sama dengan 4,0 dan 6,0 berurutan (Nicolis et al., 2021). Metode lain yang diteliti untuk memprediksi magnitudo gempa adalah kombinasi *the Internet of Things* (IoT) dan *Adaptive Neuro-Fuzzy Inference Systems* (ANFIS), yang teruji mengurangi *computational delay* sebesar 23,06 detik dengan tetap mempertahankan akurasi dan stabilitas hasil di atas 90% (Bhatia et al., 2023).



Gambar 2.1. Arsitektur CNN untuk prediksi nilai SIL (Gan, 2023)

2.1.4 *State of The Art*

Implementasi kecerdasan artifisial (AI) dalam berbagai area studi ketekniksipilan terus berkembang dan menawarkan berbagai keunggulan yang diukur baik dari segi akurasi maupun efisiensi, dalam pengambilan keputusan atau prediksi. Area-area studi tersebut mencakup prediksi perilaku seismik struktur, prediksi intensitas guncangan pada bangunan tertentu, hingga pengembangan sistem peringatan dini gempa. Metode-metode yang diteliti mayoritas meliputi beragam teknik berbasis jaringan saraf atau *Neural Network* (NN) dan sebagian teknik berbasis pohon algoritma prediksi (*decision tree*).

Tabel 2.1 menunjukkan *state of the art* dari penelitian-penelitian terdahulu dengan topik penggunaan kecerdasan buatan untuk berbagai permasalahan yang berkaitan dengan gempa. Dari berbagai penelitian terdahulu, penelitian mengenai prediksi nilai intensitas guncangan bangunan di tiap lantai dengan mempertimbangkan faktor jenis tanah, variasi material bangunan, dan jumlah lantai, belum pernah dilakukan. Dari tabel tersebut, *novelty* penelitian ini tampak jelas.

Tabel 2.1. Tabel *state of the art* penelitian kecerdasan buatan untuk kegempaan

No.	Penulis	Judul	DOI	Topik	Metode	Temuan
1	Nicolis et al. (2021)	<i>Prediction of intensity and location of seismic events using deep learning</i>	10.1016/j.spasta.2020.100442	Prediksi nilai intensitas seismik di permukaan tanah dan lokasi sumber gempa	LSTM, CNN	- Estimasi spasial dan temporal dengan LSTM menghasilkan $R^2 = 0,66$. - Akurasi 80% dicapai oleh CNN untuk memprediksi probabilitas kejadian gempa berkekuatan 4,0 atau lebih yang akan datang.
2	Luo and Paal (2022)	<i>Artificial intelligence-enhanced seismic response prediction of reinforced concrete frames</i>	10.1016/j.aei.2022.101568	Prediksi respons seismik dari struktur portal beton bertulang	AI-enhanced	Metode yang diusulkan memiliki kapabilitas prediksi dan efisiensi perhitungan yang lebih tinggi dibanding pendekatan pemodelan berbasis serat (<i>the fiber-based modelling</i>).
3	Falcone et al. (2022)	<i>Artificial neural network for technical feasibility prediction of seismic retrofitting in existing RC structures</i>	10.1016/j.istruc.2022.05.008	Optimasi perhitungan dalam pemilihan solusi perkuatan (<i>retrofitting</i>) bangunan beton bertulang	ANN	Metode yang diusulkan untuk mempercepat pemilihan solusi perkuatan bangunan.
4	Díaz et al. (2022)	<i>Machine learning techniques for estimating seismic site amplification in the Santiago basin, Chile</i>	10.1016/j.enggeo.2022.106764	Pemetaan derajat amplifikasi seismik berdasarkan integrasi data kualitatif dan kuantitatif	ML	Metode ML sebagai algoritma prediktif berpotensi besar dimanfaatkan dalam pemetaan tanah karena terbukti dapat melampaui teknik-teknik geostatistik tradisional.

Tabel 2.1. Tabel *state of the art* penelitian kecerdasan buatan untuk kegempaan

No.	Penulis	Judul	DOI	Topik	Metode	Temuan
5	Zhu et al. (2023)	<i>On-site instrumental seismic intensity prediction for China via recurrent neural network and transfer learning</i>	10.1016/j.jseaes.2023.105610	Prediksi nilai PGA dan PGV on-site yang menjadi dasar pengukuran intensitas seismik	RNN + <i>transfer learning</i>	Prediksi nilai intensitas seismik berdasarkan hasil prediksi nilai PGA dan PGV mendekati konsisten dengan hasil pengukuran.
6	Bhatia et al. (2023)	<i>Artificial intelligence based real-time earthquake prediction</i>	10.1016/j.engappai.2023.105856	Prediksi magnitudo gempa	IoT-Edge-Cloud-based systems, ANFIS	- Peningkatan efektivitas dan akurasi prediksi mencapai angka di atas 90%. - <i>Edge computing</i> mengurangi <i>computational delay</i> sebesar 23,06 detik.
7	Zhang et al. (2023)	<i>Prediction of seismic acceleration response of precast segmental self-centering concrete filled steel tube single-span bridges based on machine learning method</i>	10.1016/j.engstruct.2022.115574	Prediksi kinerja seismik dari <i>the precast segmental self-centering concrete-filled steel tube</i> (PCFST)	Conv1D-LSTM, XGboost, RFR, FEM	Metode Conv1D-LSTM mengungguli metode XGBoost dan RFR dalam memprediksi respons struktur atas dengan koefisien determinasi (R^2) berturut-turut 0,9643; 0,8780; dan 0,9623.

Tabel 2.1. Tabel *state of the art* penelitian kecerdasan buatan untuk kegempaan


No.	Penulis	Judul	DOI	Topik	Metode	Temuan
8	Li et al. (2023)	<i>Soil seismic response modeling of KiK-net downhole array sites with CNN and LSTM networks</i>	10.1016/j.engappai.2023.105990	Prediksi respons seismik tanah berdasarkan rekaman gerakan tanah	CNN, LSTM	Dibandingkan dengan model FEM, metode yang diusulkan menghasilkan prediksi yang lebih akurat dan efisien, dengan mengurangi kesalahan sebesar 40% untuk domain waktu dan 30% untuk domain frekuensi.
9	Bigdeli et al. (2023)	<i>Influence of near-field ground motions and their equivalent pulses on nonlinear seismic response of intake-outlet towers and predicting based on artificial neural networks</i>	10.1016/j.istruc.2023.04.019	Prediksi respons seismik nonlinear dari struktur menara <i>intake-outlet</i> beton bertulang yang dikenai gerakan tanah gempa dekat situs dengan arah maju	ANN	Dengan memanfaatkan ANN untuk memprediksi perpindahan dan kerusakan tarik <i>intake tower</i> , parameter-parameter persyaratan seismik pada menara yang dibebani gerakan tanah gempa dekat situs diperoleh sebesar 3,8 dan 2,7 kali dibanding ketika dibebani gerakan tanah gempa jauh, untuk arah maju dan mundur, berturut-turut.
10	Gan (2023)	<i>Design Concepts for Seismic-Resistant Buildings: Quantitative Shaking Evaluations</i>	ISBN (10): 1-5275-9146-8 ISBN (13): 978-5275-9146-2	Prediksi guncangan pada tiap lantai bangunan akibat gempa bumi tanpa mempertimbangkan jenis tanah dan jumlah lantai bangunan	CNN	Konvergensi model DNN yang dibangun terjadi dengan sangat cepat, yaitu mendekati <i>zero loss</i> dalam kurang dari 500 iterasi. Akurasi prediksi nilai SIS pada lantai dasar dan atap menghasilkan galat di bawah 10%, sedangkan pada lantai yang lain, galat terbesar adalah sekitar 20%.

2.2 Landasan Teori

Pada subbab ini, landasan teori terkait skala intensitas guncangan, analisis dinamika struktur, hingga kecerdasan buatan akan diuraikan sebagai pedoman analisis.

2.2.1 Seismic Intensity Scale (SIS)

Intensitas gempa (*seismic intensity*) adalah besaran guncangan (*shaking*) pada suatu lokasi atau bangunan yang diakibatkan oleh gempa bumi. Salah satu skala klasifikasi intensitas guncangan adalah *Seismic Intensity Scale* (SIS), yang dikembangkan oleh *Japan Meteorological Agency* (JMA). SIS terdiri dari 10 tingkatan/level intensitas guncangan, seperti ditunjukkan pada Tabel 2.2. Klasifikasi intensitas seismik didasarkan pada nilai intensitas seismik yang terukur (*measured SIS* atau mSIS). Selanjutnya dalam penelitian ini, mSIS akan disebut sebagai SIS. Prosedur perhitungan SIS mengacu pada penelitian Kawasumi (1943) yang dapat dilihat pada diagram alir pada Gambar 2.2.



Gambar 2.2. Diagram alir perhitungan nilai SIS (Kawasumi, 1943)

Perhitungan SIS dimulai dengan operasi transformasi *Fast Fourier* atau *Fast Fourier Transform* (FFT) untuk mengonversi riwayat waktu percepatan gerakan tanah $a_{x,y,z}(t)$ ke dalam bentuk digital dengan domain frekuensi ($A_{x,y,z}(f)$). Brigham (1988) mendefinisikan FFT sebagai suatu fungsi yang merepresentasikan suatu fungsi dalam domain frekuensi. Sinyal digital berdomain frekuensi tersebut kemudian difiltrasi dengan filter *bandpass* Kawasumi yang sudah dimodifikasi oleh Sakai (2018b), seperti diformulasikan dalam Persamaan 2.1 sampai 2.4.

$$\lambda_1 = (1/f)^{1/2} \quad (2.1)$$

$$\lambda_2 = \left(\frac{1 + 0,694x^2 + 0,241x^4 + 0,0557x^6 + 0,009664x^8 + 0,00134x^{10} + 0,000155x^{12}}{0,009664x^8 + 0,00134x^{10} + 0,000155x^{12}} \right)^{-1/2} \text{ dengan } x = f/10 \quad (2.2)$$

$$\lambda_3 = (1 - \exp(-(f/0,5)^3))^{1/2} \quad (2.3)$$

$$\lambda = \lambda_1 \lambda_2 \lambda_3 \quad (2.4)$$

dengan:

λ_1 : filter efek periode

λ_2 : filter *high-cut*

λ_3 : filter *low-cut*

λ : filter gabungan

f : frekuensi

Filtrasi dilakukan hingga menghasilkan transformasi percepatan terfiltrasi efek periode, *high-cut*, dan *low-cut* ($A'_{x,y,z}(f)$, $A''_{x,y,z}(f)$, dan $A'''_{x,y,z}(f)$) secara berturut-turut.

Invers FFT dilakukan untuk mengonversi kembali sinyal percepatan ke domain waktu ($a'_{x,y,z}(t)$). Selanjutnya, resultan percepatan tersebut dihitung untuk ketiga arah. Nilai resultan percepatan ini akan menjadi percepatan kumulatif 0,3 detik ($a'_{xyz}(t = 0,3)$) yang menjadi masukan untuk menghitung nilai SIS seperti pada Gambar 2.2. Pengambilan percepatan secara kumulatif selama 0,3 detik didasarkan pada hasil penelitian Ishimoto (1932) yang membuktikan bahwa dampak dari guncangan pada bangunan dan pohon mulai timbul akibat getaran gempa selama 0,3 detik. Kesimpulan dari penelitian ini adalah bahwa periode predominan gempa 0,3 detik perlu diamati dalam proses mendefinisikan risiko kerusakan bangunan. Dasar inilah yang selanjutnya digunakan dalam perhitungan nilai SIS.

Tabel 2.2. Rangkuman penjelasan tabel SIS JMA (*Japan Meteorological Agency, 2019a*)

Intensitas Seismik	Persepsi dan Reaksi Manusia	Situasi dalam Ruangan
0	Tidak dirasakan oleh orang-orang tetapi terekam dalam seismometer.	-
1	Sedikit dirasakan oleh beberapa orang yang sedang diam di dalam gedung.	-
2	Dirasakan oleh beberapa orang yang sedang diam di dalam gedung. Beberapa orang mungkin terbangun.	Benda-benda yang digantung seperti lampu berayun kecil.
3	Dirasakan oleh kebanyakan orang di beberapa gedung. Dirasakan oleh orang yang berjalan. Banyak orang terbangun.	Piring-piring di lemari berkelontang.
4	Kebanyakan orang terkejut. Dirasakan oleh kebanyakan orang berjalan. Kebanyakan orang terbangun.	Benda-benda yang digantung seperti lampu berayun secara signifikan, dan piring di lemari berkelontang. Ornamen yang tidak stabil bisa jatuh.
5-bawah	Kebanyakan orang ketakutan dan merasa perlu memegang sesuatu yang stabil.	Benda-benda yang digantung seperti lampu berayun dengan keras. Piring di lemari dan barang di rak buku bisa jatuh. Banyak ornamen yang tidak stabil jatuh. Furnitur yang tidak aman dapat berpindah, dan furnitur yang tidak stabil dapat roboh.
5-atas	Kebanyakan orang merasa sulit untuk bergerak; berjalan itu sulit tanpa berpegangan pada sesuatu yang stabil.	Piring di lemari dan barang-barang di rak buku lebih cenderung jatuh. TV bisa jatuh dari dudukannya, dan furnitur yang tidak aman bisa roboh.
6-bawah	Sulit untuk tetap berdiri.	Banyak furnitur yang tidak aman bergerak dan mungkin roboh. Pintu bisa tertutup rapat.
6-atas	Tidak mungkin untuk tetap berdiri atau bergerak tanpa merangkak.	Sebagian besar furnitur yang tidak aman bergerak, dan kemungkinan besar akan roboh.
7	Orang mungkin terlempar ke udara.	Sebagian besar furnitur yang tidak aman bergerak dan terguling, atau bahkan terlempar ke udara.

2.2.2 Klasifikasi Situs

Berdasarkan SNI 1726:2019 pasal 5, klasifikasi profil tanah di suatu situs menentukan kriteria desain seismik berupa faktor-faktor amplifikasi pada bangunan (Badan Standardisasi Nasional, 2019). Faktor-faktor yang memengaruhi klasifikasi situs adalah nilai kecepatan rambat gelombang geser pada regangan geser yang kecil, (V_s), tahanan penetrasi standar rata-rata ($\bar{N}$) atau yang biasa diidentifikasi dengan nilai NSPT, dan kuat geser niralir rata-rata ($\bar{s}_u$), pada lapisan 30 m teratas. Tabel 2.3 menyajikan detail klasifikasi situs.

Tabel 2.3. Klasifikasi situs (Badan Standardisasi Nasional, 2019)

Kelas Situs	V_s (m/s)	$\bar{N}$ atau $\bar{N}_{ch}$	$\bar{s}_u$ (kPa)
SA (batuan keras)	> 1500	N/A	N/A
SB (batuan)	750 sampai 1500	N/A	N/A
SC (tanah keras, sangat padat dan batuan lunak)	350 sampai 750	> 50	≥ 100
SD (tanah sedang)	175 sampai 350	15 sampai 50	50 sampai 100
SE (tanah lunak)	< 175	< 15	< 50
	Atau setiap profil tanah yang mengandung lebih dari 3 m tanah dengan karakteristik sebagai berikut: 1. Indeks plastisitas, $PI > 20$, 2. Kadar air, $w \geq 40\%$, 3. Kuat geser niralir $\bar{s}_u < 25 \text{ kPa}$		
SF (tanah khusus, yang membutuhkan investigasi geoteknik spesifik dan analisis respons spesifik-situs yang mengikuti 6.10.1)	Setiap profil lapisan tanah yang memiliki salah satu atau lebih dari karakteristik berikut: - Rawan dan berpotensi gagal atau runtuh akibat beban gempa seperti mudah likuifaksi, lempung sangat sensitif, tanah tersementasi lemah - Lempung sangat organik dan/atau gambut (ketebalan $t_s > 3 \text{ m}$) - Lempung berplastisitas sangat tinggi (ketebalan $t_s > 7,5 \text{ m}$ dengan indeks plastisitas $PI > 75$) - Lempung lunak/setengah teguh dengan ketebalan $t_s > 35 \text{ m}$ dengan $\bar{s}_u < 50 \text{ kPa}$		

CATATAN: N/A = tidak dapat dipakai


2.2.3 Analisis Riwayat Waktu Gempa

Analisis riwayat waktu adalah metode analisis yang melibatkan penerapan beban seismik berdasarkan riwayat waktu gerakan permukaan tanah untuk mengevaluasi perilakunya. Analisis ini biasanya digunakan untuk kasus nonlinear dan struktur berderajat banyak (Wilson, 2000). SNI 1726:2019 pasal 11.2.2 memberi acuan mengenai jumlah gerakan tanah yang harus dipilih untuk analisis riwayat waktu nonlinear, yaitu tidak kurang dari sebelas pasang.

2.2.4 Analisis Dinamika Struktur Model *Lumped-Mass*

2.2.4.1 Teori Dasar Analisis Dinamika Struktur

Sistem *Multi-Degree of Freedom* (MDOF) khususnya model *lumped-mass* adalah suatu sistem idealisasi yang mendiskretisasi struktur ke dalam beberapa derajat kebebasan untuk dapat dianalisis khususnya perilaku dinamisnya (Chopra, 2020). Penurunan persamaan gerakan pada model *lumped-mass* mengacu pada idealisasi struktur portal 2 lantai yang dikenai beban eksternal $p_1(t)$ dan $p_2(t)$ (Gambar 2.3a). Gaya-gaya yang bekerja pada tiap lantai dideskripsikan pada Gambar 2.3b, yaitu meliputi gaya-gaya luar, gaya tahanan elastik (atau inelastik) f_{Si} , dan gaya redaman f_{Di} .



Gambar 2.3. (a) Portal geser 2 lantai; (b) gaya-gaya yang terjadi pada kedua massa

Persamaan gerakan yang digunakan pada sistem MDOF dituliskan dalam Persamaan 2.5 dengan penjabaran dalam Persamaan 2.3 dan 2.7.

$$\begin{bmatrix} m_1 & 0 \\ 0 & m_2 \end{bmatrix} \begin{Bmatrix} \ddot{u}_1 \\ \ddot{u}_2 \end{Bmatrix} + \begin{Bmatrix} f_{D1} \\ f_{D2} \end{Bmatrix} + \begin{Bmatrix} f_{S1} \\ f_{S2} \end{Bmatrix} = \begin{Bmatrix} p_1(t) \\ p_2(t) \end{Bmatrix} \quad (2.5)$$

di mana:

$$\begin{Bmatrix} f_{D1} \\ f_{D2} \end{Bmatrix} = \begin{bmatrix} c_1 + c_2 & -c_2 \\ -c_2 & c_2 \end{bmatrix} \begin{Bmatrix} \dot{u}_1 \\ \dot{u}_2 \end{Bmatrix} \quad (2.6)$$

dan

$$\begin{Bmatrix} f_{S1} \\ f_{S2} \end{Bmatrix} = \begin{bmatrix} k_1 + k_2 & -k_2 \\ -k_2 & k_2 \end{bmatrix} \begin{Bmatrix} u_1 \\ u_2 \end{Bmatrix} \quad (2.7)$$

dengan:


m_i : massa lantai ke- i

$\ddot{u}_i$: percepatan struktur lantai ke- i

- $\dot{u}_i$: kecepatan struktur lantai ke- i
 u_i : perpindahan struktur lantai ke- i
 c_i : koefisien viskositas redaman lantai ke- i
 k_i : kekakuan lateral struktur lantai ke- i

2.2.4.2 Estimasi Kekakuan Tiap Lantai dengan Metode Bentuk Ragam Translasi Lateral Dasar

Studi mengenai estimasi kekakuan tiap lantai pernah dilakukan oleh Vijayanarayanan et al. (2017) dengan membandingkan beberapa metode. Dari penelitian yang dilakukan, metode bentuk ragam translasi lateral dasar (*fundamental lateral translational mode shape method*) menghasilkan hasil yang paling memuaskan. Gambar 2.4 mengilustrasikan ekivalensi model numerik dan matematik struktur beberapa lantai dalam metode ini.



K_i : Lateral translational stiffness of storey i ;
 m_p : Seismic mass lumped at each node p of storey i ;
 m_i : Seismic mass of storey i

Gambar 2.4. Ilustrasi ekivalensi model numerik dan matematik struktur beberapa lantai (Vijayanarayanan et al., 2017)

Pada metode ini, kekakuan tiap lantai diestimasi berdasarkan massa tiap lantai dan hasil analisis ragam (*modal analysis*) dari struktur, yaitu periode natural dan bentuk ragam (*mode shape*) yang terasosiasi. Persamaan 2.8 menyajikan formula untuk mengevaluasi kekakuan tiap lantai,

$$\{K_i; \dots; K_{n-1}; K_n\}^T = \left\{ \left[\frac{\omega^2 \sum_{l=1}^n m_l \phi_l}{\phi_1} \right]; \dots; \left[\frac{\omega^2 \sum_{l=1}^n m_l \phi_l}{\phi_{n-1} - \phi_{n-2}} \right]; \left[\frac{\omega^2 \sum_{l=1}^n m_l \phi_l}{\phi_{n-1} - \phi_{n-2}} \right] \right\}^T \quad (2.8)$$

dengan K_i dan m_i adalah kekakuan translasi lateral dan massa seismik terkumpul (*lumped*) pada lantai ke- i , n adalah jumlah lantai, ω dan ϕ_i adalah frekuensi sirkular dasar struktur dan bentuk ragam translasi lateral dasar ke- i . Dengan penggunaan karakter

dinamik struktur ω dan ϕ_i yang terasosiasi dengan massa lantai m_i , metode ini menghasilkan estimasi kekakuan lantai K_i (Persamaan 2.8) yang unik dan tidak berubah seiring pemilihan *input* seperti distribusi gaya lateral.

2.2.4.3 Redaman Rayleigh

Redaman Rayleigh merupakan salah satu metode mengonstruksi matriks redaman secara klasik yang cukup konsisten dengan data eksperimental (Chopra, 2020). Formula redaman Rayleigh disajikan pada Persamaan 2.9,

$$C = a_0 M + a_1 K \quad (2.9)$$

dengan M dan K adalah matriks massa dan kekakuan struktur, a_0 dan a_1 adalah koefisien-koefisien yang dipengaruhi oleh rasio redaman (ξ) dan frekuensi natural struktur (ω) mode ke- i dan j , seperti ditunjukkan pada Persamaan 2.10 dan 2.11.

$$a_0 = \xi \frac{2\omega_i \omega_j}{\omega_i + \omega_j} \quad (2.10)$$

$$a_1 = \xi \frac{2}{\omega_i + \omega_j} \quad (2.11)$$

2.2.4.4 Analisis Dinamika Struktur dengan Pemodelan Kerucut pada Fondasi

Analisis dinamika struktur untuk model *lumped-mass* dengan variasi jenis tanah perlu mempertimbangkan perilaku dinamis dari struktur bawah (fondasi) yang lebih spesifik. Model kerucut (*cone model*) yang telah digunakan dalam penelitian Ahmadi et al. (2015) merupakan salah satu model yang dapat merepresentasikan perilaku dinamis fondasi (Gambar 2.5). Dalam penelitian ini, koefisien kekakuan dan redaman pada fondasi, baik translasional (k_s, c_s) maupun rotasional (k_φ, c_φ), serta momen inersia pada bagian fondasi (ΔM_φ), diformulasikan dengan mempertimbangkan parameter material tanah, seperti diuraikan dalam Persamaan 2.12 hingga 2.16.

$$k_s = \frac{8\rho_s V_s^2 r}{2-\nu} \quad (2.12)$$

$$c_s = \pi \rho_s V_s r^2 \quad (2.13)$$

$$k_\varphi = \frac{8\rho_s V_a^2 r^3}{3(1-\nu)} \quad (2.14)$$

$$c_\varphi = \frac{\pi \rho_s V_a r^4}{4} \quad (2.15)$$

$$\Delta M_\varphi = 0,3\pi(\nu - 0,33)\rho_s r^5 \quad (2.16)$$

dengan:


ρ_s : massa jenis tanah

ν : rasio Poisson tanah

V_s : kecepatan rambat gelombang geser pada tanah

V_a : kecepatan rambat gelombang aksial pada tanah

r : radius fondasi



Gambar 2.5. Model *lumped-mass* dengan fondasi *cone model* (Ahmadi et al., 2015)

Model interaksi tanah-struktur yang dikenai gelombang geser arah horizontal ini memiliki persamaan umum dinamika struktur seperti ditulis pada Persamaan 2.17 dan dijabarkan dalam Persamaan 2.18 hingga 2.21. Pada persamaan-persamaan tersebut, M , K , dan C yang berasosiasi dengan indeks n adalah matriks massa, kekakuan, dan redaman struktur atas, n adalah jumlah lantai di atas fondasi, I_i adalah momen inersia di lantai ke- i , h_i adalah jarak dari elevasi lantai- i ke dasar, dan $u_{g(t)}$ adalah riwayat waktu percepatan gempa. Rasio massa fondasi (m_b) dengan total massa struktur atas (M_{up}) memenuhi $0,2 \leq m_b/M_{up} \leq 0,5$. Sementara itu, nilai-nilai parameter jenis tanah seperti c_s , c_ϕ , k_s , k_ϕ , dan ΔM_ϕ dihitung dengan mengacu pada Persamaan 2.12 hingga 2.16.

$$[M]\{\ddot{u}\} + [C]\{\dot{u}\} + [K]\{u\} = -[M]\{R\}u_{g(t)} \quad (2.17)$$

dengan:

$$[M] = \begin{bmatrix} M_{n \times n} & 0 & 0 \\ 0 & m_b & 0 \\ 0 & 0 & \sum_{i=0}^n I_i + \Delta M_\varphi \end{bmatrix} \quad (2.18)$$

$$[C] = \begin{bmatrix} C_{n \times n} & C_{n \times 1} & -hc_1 \\ C_{1 \times n} & c_1 + c_s & hc_1 \\ -hc_1 & hc_1 & c_\varphi + \sum_{i=0}^n h_i^2 c_i \end{bmatrix} \quad (2.19)$$

$$[K] = \begin{bmatrix} K_{n \times n} & K_{n \times 1} & -hk_1 \\ K_{1 \times n} & k_1 + k_s & hk_1 \\ -hk_1 & hk_1 & k_\varphi + \sum_{i=0}^n h_i^2 k_i \end{bmatrix} \quad (2.20)$$

$$\{R\} = \{1, \dots, 1, 0\}^T \quad (2.21)$$

2.2.4.5 Integrasi Numerik Metode Beta-Newmark

Penyelesaian persamaan dinamika struktur (Persamaan 2.17) melibatkan operasi integrasi numerik. Salah satu teknik atau metode integrasi numerik yang umum digunakan adalah metode Beta-Newmark (Chopra, 2020). Pada sistem akselerasi linear, metode Beta-Newmark dapat menghasilkan respons dinamika bangunan yang meliputi perpindahan, kecepatan, dan percepatan, akibat gerakan tanah. Respons tersebut dihitung untuk setiap langkah waktu (*time step*) i dengan formulasi seperti pada Persamaan 2.22 hingga 2.24,

$$u_{i+1} = \frac{\hat{p}_{i+1}}{\hat{K}} \quad (2.22)$$

$$\dot{u}_{i+1} = \frac{\gamma}{\beta \Delta t} (u_{i+1} - u_i) + \left(1 - \frac{\gamma}{\beta}\right) \dot{u}_i + \Delta t \left(1 - \frac{\gamma}{2\beta}\right) \ddot{u}_i \quad (2.23)$$

$$\ddot{u}_{i+1} = \frac{\gamma}{\beta \Delta t^2} (u_{i+1} - u_i) - \frac{1}{\beta \Delta t} \dot{u}_i - \left(\frac{\gamma}{2\beta} - 1\right) \ddot{u}_i \quad (2.24)$$

dengan kondisi awal ($i = 0$) adalah sebagai berikut (Persamaan 2.25 hingga 2.30):

$$\hat{P}_{i+1} = P_{i+1} + A_1 u_i + A_2 \dot{u}_i + A_3 \ddot{u}_i \quad (2.25)$$

$$\hat{K} = K + A_1 \quad (2.26)$$

$$A_1 = \frac{1}{\beta \Delta t^2} M + \frac{\gamma}{\beta \Delta t} C \quad (2.27)$$

$$A_2 = \frac{1}{\beta \Delta t} M + \left(\frac{\gamma}{\beta} - 1\right) C \quad (2.28)$$

$$A_3 = \left(\frac{1}{2\beta} - 1\right) M + \Delta t \left(\frac{\gamma}{2\beta} - 1\right) C \quad (2.29)$$

$$\ddot{u}_{i=0} = \frac{-M \ddot{u}_{g,i=0} - C \dot{u}_{i=0} - K u_{i=0}}{M} \quad (2.30)$$

di mana P_{i+1} adalah gaya inersia akibat gerakan tanah pada langkah waktu pertama (setelah kondisi awal) dan seterusnya, K adalah matriks kekakuan struktur, M adalah matriks massa struktur, dan C adalah matriks redaman struktur.

Metode Beta-Newmark dengan akselerasi linear menggunakan parameter β dan γ yang menentukan stabilitas dan akurasi hitungan. Jika rasio interval waktu Δt untuk analisis dinamik dengan periode natural struktur T_n lebih kecil atau sama dengan 0,551 (Persamaan 2.31), maka nilai $\beta = 1/6$ dan $\gamma = 1/2$ akan memberikan hasil yang stabil dan akurat.

$$\frac{\Delta t}{T_n} \leq 0,551 \quad (2.31)$$

2.2.5 Artificial Intelligence (AI)


Artificial intelligence (AI) adalah suatu teknologi untuk melakukan otomasi pekerjaan-pekerjaan intelektual yang biasanya dikerjakan manusia (Chollet, 2021). *Machine learning* (ML) adalah bagian dari AI yang memiliki spesifikasi lebih khusus yaitu kemampuan mempelajari sesuatu (dilatih/*trained*). ML mencari representasi yang berguna dari beberapa data input, dalam ruang kemungkinan yang telah ditentukan sebelumnya, menggunakan panduan dari sinyal umpan balik. Tiga metode ML yang populer adalah *Neural Network* (NN), *Convolutional Neural Network* (CNN), dan *Gradient Boosting* (GB).

2.2.5.1 Neural Network (NN)

Deep learning atau *Deep Neural Network* (DNN) adalah bagian spesifik dari ML yang merupakan cara baru untuk mempelajari representasi dari data yang menekankan pada pembelajaran lapisan-lapisan (*layers*) representasi yang semakin bermakna secara berurutan. Istilah “*deep*” menggambarkan jumlah lapisan yang berkontribusi pada sebuah model data, sedangkan “*neural network*” mendeskripsikan model jaringan pembelajaran representasi berlapis.

Setiap lapisan memiliki bobot (*weights*) untuk menyimpan spesifikasi atas apa yang dikerjakan pada input data dalam lapisan. Himpunan nilai bobot-bobot dari semua lapisan dalam sebuah jaringan dicari hingga jaringan tersebut dapat memetakan *input* data dengan targetnya yang bersesuaian. Proses inilah yang disebut dengan “*learning*” atau “*training*”. Di dalam proses pembelajaran (*learning*), terdapat beberapa istilah yang penting untuk diketahui, yaitu *loss function*, *loss score*, *backpropagation algorithm*. *Loss*


function adalah fungsi untuk mengontrol *output* dari *neural network* dengan mengukur seberapa jauh *output* dari target yang diekspektasikan. Ukuran tersebut disebut *loss score*. Optimasi proses *learning* dilakukan dengan menjalankan sebuah algoritma, *backpropagation algorithm*, yaitu algoritma berulang (*looping*) untuk mengoptimasi proses *learning* dengan mengirimkan sinyal balik (*feedback signal*) berupa *loss score* tiap iterasi untuk dijadikan dasar pengaturan ulang *weights*, hingga diperoleh *loss score* sesuai keinginan. Pola kerja DNN ditunjukkan dalam diagram alir pada Gambar 2.6.



Gambar 2.6. Pola kerja DNN (Chollet, 2021)

2.2.5.2 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah suatu arsitektur dalam metode DNN yang mempelajari data secara langsung (The MathWorks, 2017a). CNN terdiri dari lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan luaran (*output layer*). Lebih spesifik, *hidden layer* pada CNN terdiri dari lapisan-lapisan konvolusi (*convolution layer*) dan lapisan-lapisan lain yang dibutuhkan dalam proses belajar (*data training*), baik dalam proses ekstraksi fitur maupun klasifikasi. Pada dasarnya, CNN sangat cocok digunakan dalam memproses klasifikasi gambar seperti ditunjukkan pada Gambar 2.7. Namun, CNN juga dapat dimanfaatkan untuk berbagai aplikasi seperti pengolahan teks, sinyal, dan respons kontinu lainnya (The MathWorks, 2017b).




Gambar 2.7. Contoh skema CNN (The MathWorks, 2017a)


Lapisan masukan (*input layer*) pada metode CNN tersusun dalam bentuk matriks (*batch*), seperti rangkaian piksel-piksel dalam suatu gambar digital. Masing-masing piksel atau *entry* dalam matriks mengandung informasi/data tertentu. Normalisasi data biasanya dilakukan sebelum proses selanjutnya dikerjakan (The MathWorks, 2017c).

Setelah data *input* dinormalisasi, proses konvolusi dikerjakan dalam lapisan konvolusi (The MathWorks, 2017c). Lapisan ini terdiri dari filter atau *kernel*, yaitu himpunan bobot (*weights*) yang diaplikasikan pada bagian (*region*) tertentu dari matriks *input*. Dalam proses konvolusi, seluruh bagian dalam matriks *input* akan dipindai dan difiltrasi oleh filter secara bergeser (*sliding*) dari satu bagian ke bagian lain secara lokal-regional, sesuai ukuran filter dan *stride* (ukuran langkah filter saat bergeser). Proses ini menghasilkan ekstraksi fitur yang telah memperhitungkan bobot dan bias pada lapisan yang ditinjau, yang disebut peta fitur (*features maps*). Pada CNN, bobot (*w*) dan bias (*b*) untuk seluruh jaringan dalam suatu lapisan bernilai sama.


Proses konvolusi diilustrasikan dalam Gambar 2.8 hingga Gambar 2.11, di mana masing-masing gambar merepresentasikan tiap langkah dalam proses filtrasi. Dalam contoh ilustrasi ini, ukuran batch input adalah 4×4 , sedangkan ukuran filter adalah 2×2 . *Stride* pada ilustrasi ini adalah dua (2), ditunjukkan dengan pola pergeseran filter dari gambar satu ke gambar selanjutnya, di mana filter bergeser sejauh dua *entry input* ke kanan. Proses ekstraksi fitur dilakukan dengan mengalkulasikan nilai-nilai *input* dengan bobot dan bias yang nilainya sama pada semua langkah.




Gambar 2.8. Ilustrasi filtrasi pertama dalam lapisan konvolusi (The MathWorks, 2017a)



Gambar 2.9. Ilustrasi filtrasi kedua dalam lapisan konvolusi (The MathWorks, 2017a)



Gambar 2.10. Ilustrasi filtrasi ketiga dalam lapisan konvolusi (The MathWorks, 2017a)



Gambar 2.11. Ilustrasi filtrasi keempat dalam lapisan konvolusi (The MathWorks, 2017a)

Dalam *The MathWorks* (2017b), lapisan normalisasi *batch* (*batch normalization*) diaplikasikan di antara *convolutional layers* dan lapisan non-linear seperti *Rectified Linear Unit* (ReLU) untuk mempercepat proses pelatihan CNN dan mengurangi sensitivitas pada inisialisasi jaringan. Lapisan ini menormalisasi proses-proses aktivasi di setiap kanal dengan mengurangi nilai rata-rata *mini-batch* dan membaginya dengan deviasi standar *mini-batch*. Setelah itu, lapisan ini mengganti input dengan nilai *offset* yang dapat dipelajari (β_{CNN}) dan menskalakannya dengan faktor skala yang dapat dipelajari (γ_{CNN}). Kedua parameter tersebut selalu diperbarui (*updated*) selama proses pelatihan. Dengan menormalisasi proses-proses aktivasi dan perambatan gradien melalui *neural network*, *batch normalization* membuat proses optimasi dalam pelatihan jaringan menjadi lebih mudah.

Fungsi aktivasi nonlinear yang mengikuti lapisan konvolusi dan *batch normalization* adalah *Rectified Linear Unit* (ReLU). Fungsi aktivasi ReLU tidak mengubah ukuran *input*. ReLU melakukan operasi pembatasan pada tiap elemen, di mana setiap nilai yang kurang dari nol (0) akan disesuaikan menjadi nol seperti ditunjukkan pada Persamaan 2.32.

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.32)$$

Lapisan lain dalam CNN yang berfungsi untuk mengurangi jumlah koneksi ke lapisan-lapisan selanjutnya adalah lapisan pengumpulan (*pooling layers*). Pada dasarnya, lapisan ini tidak melakukan proses pelatihan, melainkan hanya melakukan pengurangan jumlah parameter untuk dipelajari pada lapisan selanjutnya. Operasi pada *pooling layer*

dapat berupa *max pooling* dan *average pooling layer*. *Max pooling layer* membagi input dalam beberapa *region* sesuai jumlah *region* pengumpulan yang diinginkan, lalu menghitung nilai maksimum pada tiap *region*. Sementara itu, *average pooling layer* membagi input dalam beberapa *region* sesuai jumlah *region* pengumpulan yang diinginkan, lalu menghitung nilai rerata pada tiap *region*.

Setelah melalui tahap pembelajaran fitur, proses CNN dilanjutkan dengan tahap klasifikasi. Tahap ini membutuhkan suatu lapisan operasi yang menghubungkan seluruh jaringan pada lapisan sebelumnya, yang dinamakan lapisan terhubung penuh (*fully connected layer*). Lapisan ini mengkombinasikan seluruh fitur yang sudah dipelajari pada tahap sebelumnya untuk mengidentifikasi pola yang lebih besar. Dalam kasus klasifikasi, *fully connected layer* yang terakhir mengkombinasikan seluruh fitur untuk mengklasifikasikan gambar.

Tahap terakhir dalam CNN terdiri dari lapisan-lapisan luaran (*output layers*). Untuk kasus regresi, *loss function* yang umum digunakan adalah *mean squared error* (MSE). Rumus MSE disajikan pada Persamaan 2.33, dengan Y' adalah nilai hasil prediksi model CNN, sedangkan Y adalah nilai target, seperti pada Gambar 2.5.

$$L = (Y' - Y)^2 \quad (2.33)$$

Dari nilai *loss score*, proses pelatihan akan dilanjutkan ke optimasi bobot dan bias untuk dilakukan pelatihan kembali. Formula optimasi bobot yang digunakan salah satunya adalah *stochastic gradient descent with momentum* (SGDm), seperti ditunjukkan pada Persamaan 2.34 dan 2.35,

$$W' = W - v_{CNN} \quad (2.34)$$

$$v'_{CNN} = \gamma_{CNN} v_{CNN} + \eta \frac{\delta L}{\delta W} \quad (2.35)$$

dengan W' adalah nilai bobot baru (setelah dioptimasi), W adalah nilai bobot lama, v dan v' adalah *weighted average* dari gradien baik sebelum maupun sesudah optimasi, γ adalah suatu hiperparameter yang biasa diambil 0,5; 0,9; atau 0,99, η adalah nilai *learning rate*, dan $\frac{\delta L}{\delta W}$ adalah gradien *loss* terhadap *weight*.

Pelatihan ulang dengan modifikasi bobot dan bias pada tiap iterasinya ini dikerjakan hingga diperoleh *loss score* kurang dari *loss score* maksimum yang ditetapkan. Algoritma pelatihan ini disebut *backpropagation* (perambatan mundur).

2.2.5.3 Gradient Boosting (GB)

Gradient Boosting (GB) merupakan metode ML yang berbasis pohon algoritma prediksi (*decision trees*). Metode yang mengimplementasikan teknik *ensemble* (penggabungan) ini dipopulerkan oleh Friedman (2001). Teknik *ensemble* adalah teknik yang berbasis penggabungan sejumlah model pembelajar lemah (*weak learners*) untuk menghasilkan satu model prediksi tunggal yang kinerjanya lebih unggul (*strong learner*).

Dalam metode GB, proses generalisasi dapat dilakukan dengan optimasi pada *loss function* yang dapat didiferensiasi secara arbitrer. Konsep ini memandang proses *boosting* sebagai sebuah masalah optimasi numerik dalam ruang fungsi. Algoritma ini secara iteratif membangun sebuah model aditif, di mana setiap *weak learner*, biasanya *decision tree*, dilatih untuk menyesuaikan diri dengan *pseudo-residual* dari model sebelumnya. *Pseudo-residual* ini pada dasarnya adalah gradien (turunan negatif) dari *loss function* terhadap prediksi model pada tahap tersebut. Teknik ini tidak hanya mencoba memperbaiki kesalahan prediksi, melainkan juga menggerakkan prediksi ke arah yang paling curam dalam mengurangi *loss*.

Algoritma metode GB dimulai dari inisialisasi model menggunakan nilai konstan, dengan mencari nilai prediksi *weak learner* (γ_{GB}) yang meminimalisasi nilai *loss* untuk menetapkan nilai konstan awal (F_0), seperti pada Persamaan 2.36. Proses minimalisasi tersebut dinotasikan dengan *argmin*. Fungsi $L(y_i, \gamma)$ adalah *loss function* antara nilai target (y_i) dan prediksi *weak learner* (γ_{GB}) mulai dari data pertama (indeks i) hingga total data n .

$$F_0(x) = \underset{\gamma_{GB}}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, \gamma_{GB}) \quad (2.36)$$

Selanjutnya merupakan proses iterasi sejumlah pohon (*trees*) yang ditentukan. Proses ini terdiri dari hitungan residual, pelatihan pohon regresi (*regression tree*), hitungan nilai prediksi untuk tiap titik terminal (*terminal node*) atau daun (*leaf*), dan pembaharuan model secara aditif dengan nilai prediksi keseluruhan. Hitungan residual diuraikan dalam Persamaan 2.37, dengan q adalah indeks *tree*.

$$r_{iq} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{q-1}(x)} \quad \text{untuk } i = 1, \dots, n \quad (2.37)$$

Nilai residual tersebut kemudian digunakan dalam pelatihan *regression tree* beriringan dengan fitur-fitur x untuk membuat *terminal node* R_{jq} sesuai dengan jumlah total daun (J) pada iterasi tersebut (indeks q). *Terminal node* tersebut menentukan

cakupan sampel pada tahap selanjutnya, yaitu perhitungan nilai prediksi *weak learner* di tiap daun (γ_{jq}), seperti ditunjukkan pada Persamaan 2.38. Dalam persamaan ini, nilai *loss* dihitung berdasarkan prediksi keseluruhan pada iterasi sebelumnya, maka digunakan notasi F_{q-1} .

$$\gamma_{jq} = \underset{\gamma_{GB}}{\operatorname{argmin}} \sum_{x_i \in R_{jq}} L(y_i, F_{q-1}(x_i) + \gamma) \quad \text{untuk } j = 1, \dots, J_q \quad (2.38)$$

Tahap akhir adalah pembaharuan (*update*) model, di mana hasil prediksi keseluruhan model (*strong learner*) dihasilkan. Persamaan 2.39 merumuskan hasil prediksi tersebut yang merupakan penjumlahan dari hasil prediksi sebelumnya dengan gabungan prediksi *weak learner* yang dikalikan dengan *learning rate* (ν_{GB}). Proses iterasi ini dilakukan hingga memperoleh nilai *loss* yang memenuhi batas yang ditentukan.

$$F_q(x) = F_{q-1}(x) + \nu_{GB} \sum_{j=1}^{J_q} \gamma_{jq} 1(x_i \in R_{jq}) \quad (2.39)$$

2.3 Kerangka Berpikir

Perhitungan nilai intensitas guncangan bangunan akibat gempa dengan metode numerik membutuhkan waktu yang cukup panjang. Sementara itu, sistem mitigasi bencana khususnya sistem peringatan dini gempa membutuhkan proses hitungan yang sangat cepat. Salah satu metode yang memungkinkan untuk dikembangkan dan memenuhi kebutuhan prediksi nilai intensitas guncangan secara cepat dan mendekati akurat adalah *artificial intelligence* (AI).

Dalam pengembangan model AI untuk prediksi intensitas guncangan bangunan, pengumpulan data raya (*big data*) perlu dilakukan. Data raya yang dikumpulkan adalah data hasil analisis struktur model *lumped-mass* dengan analisis riwayat waktu. Faktor-faktor yang menjadi variasi data raya meliputi data jenis tanah, material bangunan, jumlah lantai bangunan, dan data gempa (magnitudo, jarak episentrum, dan kedalaman hiposentrum). Hasil analisis struktur tersebut adalah data nilai intensitas guncangan dari berbagai faktor pengaruh. Sejumlah data digunakan sebagai data pelatihan, sedangkan sebagian data lainnya sebagai data untuk uji validasi dan prediksi. *Big data* yang sudah dikembangkan akan menjadi *input* dalam proses pembelajaran (*learning/training*) model AI. Pengembangan model AI untuk prediksi nilai intensitas guncangan perlu dievaluasi akurasi dalam tahap uji validasi. Hasil dari penelitian ini diharapkan dapat membantu proses prediksi nilai intensitas gempa dengan cepat dan akurat.